


「日常会話コーパス」モニター版『ひまわり』講習会

著者	山口 昌也
ページ	1-42
URL	http://doi.org/10.15084/00003107



「日常会話コーパス」モニター版 『ひまわり』講習会

山口昌也(国立国語研究所)



本日の内容

- ▶ 全文検索システム『ひまわり』を使った『日本語日常会話コーパス』の利用方法を紹介
 - ▶ 『日本語日常会話コーパス』(モニタ公開版の講習会用パッケージ)
 - ▶ 『ひまわり』(ver.1.6.4)
 - ▶ FishWatchr (ver.0.9.15b)
- ▶ 全体的な流れ
 - ▶ 講習会用パッケージの説明
 - ▶ 『ひまわり』の紹介と基本的な使い方
 - ▶ 検索機能の詳細
 - ▶ コーパスの基礎情報の集計とコーパスの構造
 - ▶ 動画の閲覧・アノテーション

『ひまわり』とは

▶ 言語研究用の全文検索システム

- ▶ 指定された文字列を網羅的に検索して、前後文脈付きで結果を表示します(コンコードンサ)
- ▶ 『太陽コーパス』(20世紀初頭の総合雑誌『太陽』)用の検索システムとして構築しました

▶ 特徴

- ▶ XMLでタグづけされたコーパスを全文検索できます
- ▶ Windows, Mac OS, Linux など、多くのOS上で動作します
- ▶ 無料です

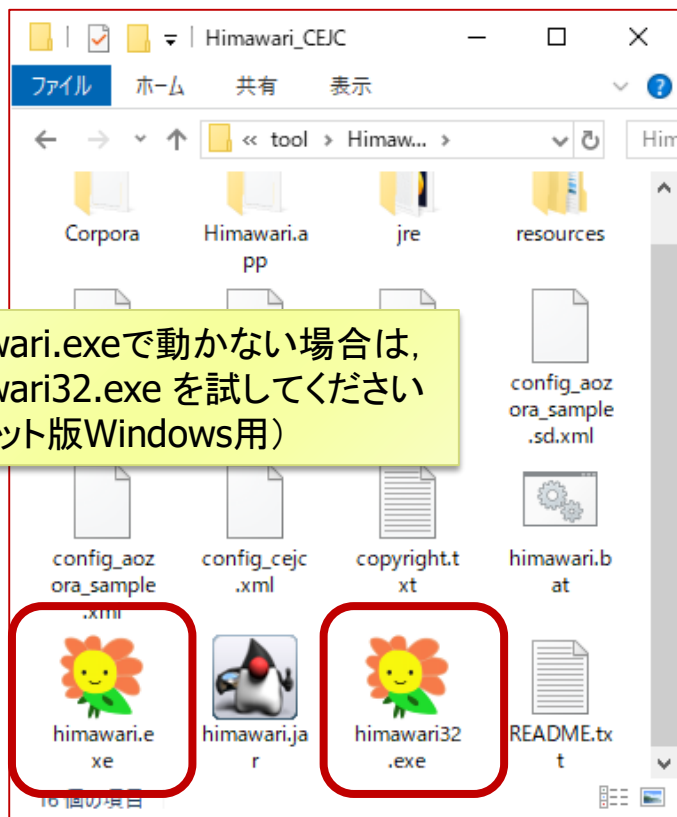
Ver.1.6 ⇒ 統計的な分析に必要なデータの収集支援機能を強化
(例:総文字数, 総単語数)

『ひまわり』の基本的な使い方 (CEJC編)

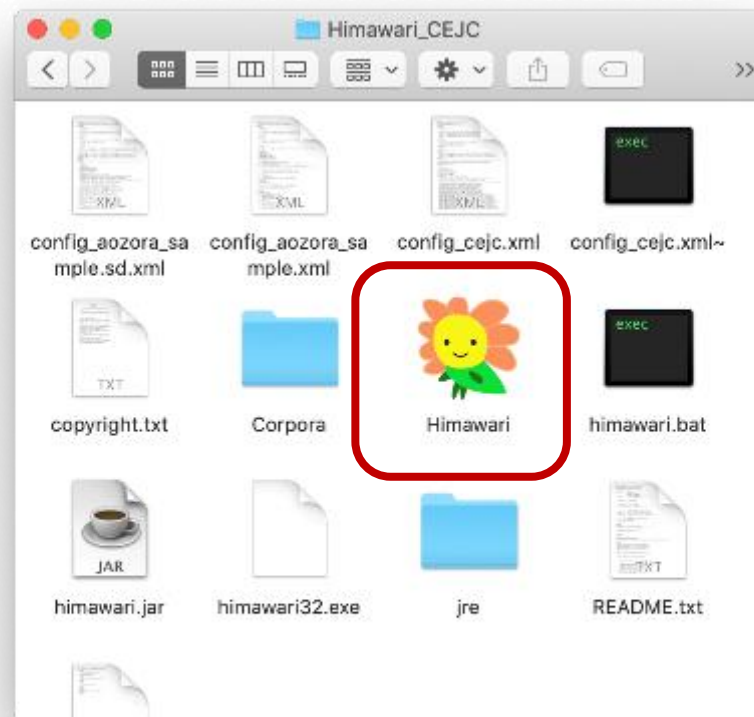
『ひまわり』を起動する

▶ tool ⇒ Himawari_CEJC フォルダ

□ Windowsの場合

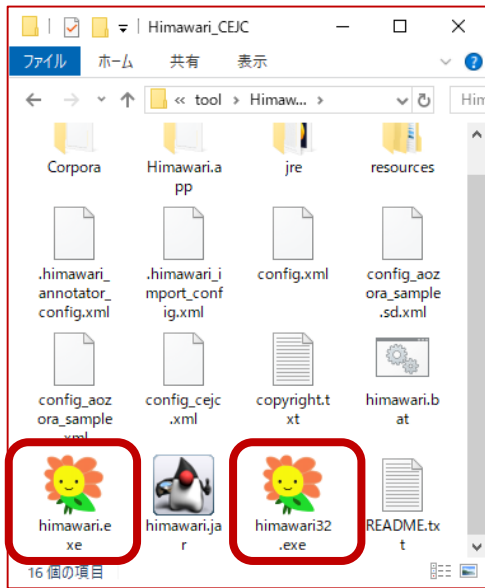


□ macOSの場合

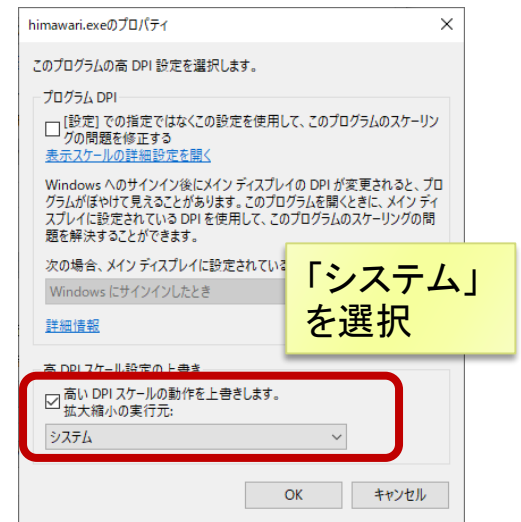
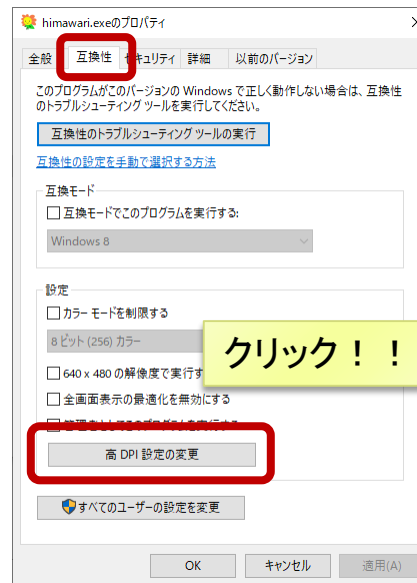


トラブルシューティング(2)

▶ Windowsで『ひまわり』の文字が小さすぎる

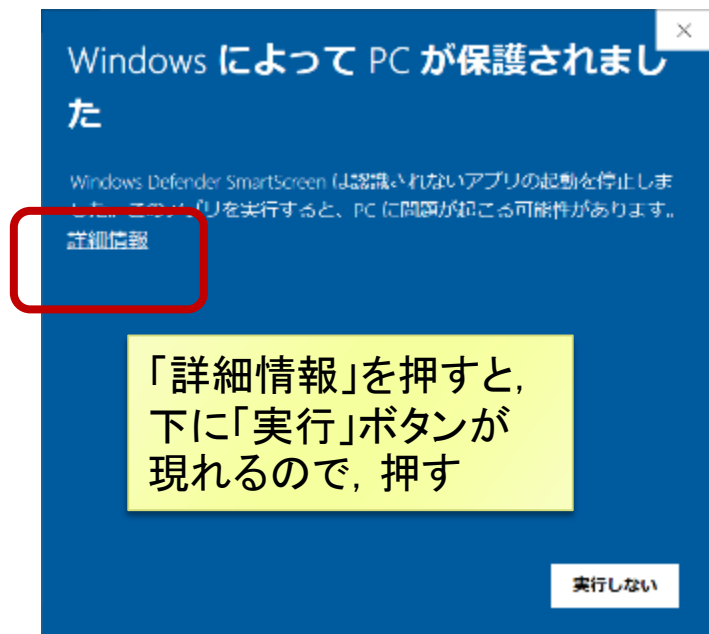


himawari.exe (himawari32.exe)を
右クリックして、プロパティを選択



トラブルシューティング(3)

▶ 起動時にエラーが出る (Windowsの場合)



▶ 起動時にエラーが出る (macOSの場合)

- ▶ ダウンロードした講習会用パッケージは、正常に動作しません。
- ▶ 別途ファイルを配布しますので、ご相談ください。

検索する

「検索文字列」欄では
右クリックで履歴表示

全文検索システムひまわり - [日本語日常会話コーパス] - config.xml

ファイル 編集 ツール ヘルプ

検索文字列 フィルタ コーパス 検索オプション

検索文字列

全文 じゃん

前文脈

後文脈

で終る

で始まる

検索

字体変換

クリア

検索の実行

no	前文脈	キー	後文脈	会話ID	話者ID	話者ラベル	性別
1	ナはあの小ささがいい	じゃん	◇ あの細長さでさ	T010_004	T010	IC01_徹	男性
2	だよ キャッチする人	じゃん	◇ お前超怖えから	T010_004	T010_004	IC02_大場	男性
3	器吹い 腹式やってん	じゃん	◇ やってるにも関	T010_004	T010	IC01_徹	男性
4	てもう就活始まってる	じゃん	ああ だから今年度	T004_001	T004_002	IC03_さと...	男性
5	ついてね あれもあん	じゃん	あのタッチするやつ	T010_004	T010	IC01_徹	男性
6	だからカットしに来る	じゃん	あー はいはいはい	T010_004	T010	IC01_徹	男性
7	ん うん ばちーなる	じゃん	あー 俺痛いじゃん	T010_004	T010	IC01_徹	男性
8	かみたいでさ全部やる	じゃん	うん うん あー	T010_004	T010_003	IC03_龍之...	男性
9	回ナセカンドに投げん	じゃん	うん うん うん	T010_004	T010	IC01_徹	男性
10	だからキャッチャー	じゃん	うん うん うん	T010_004	T010	IC01_徹	男性
11	たら絶対もう合わない	じゃん	うん うん だから	T010_004	T010	IC01_徹	男性
12	いや みんなねゆう	じゃん	うん うん んで俺	T010_004	T010	IC01_徹	男性
13	ヒットも一本のヒット	じゃん	うん うん うん じ	T010_004	T010_004	IC02_大場	男性

途中経過の表示

検索総数: 71

検索総数

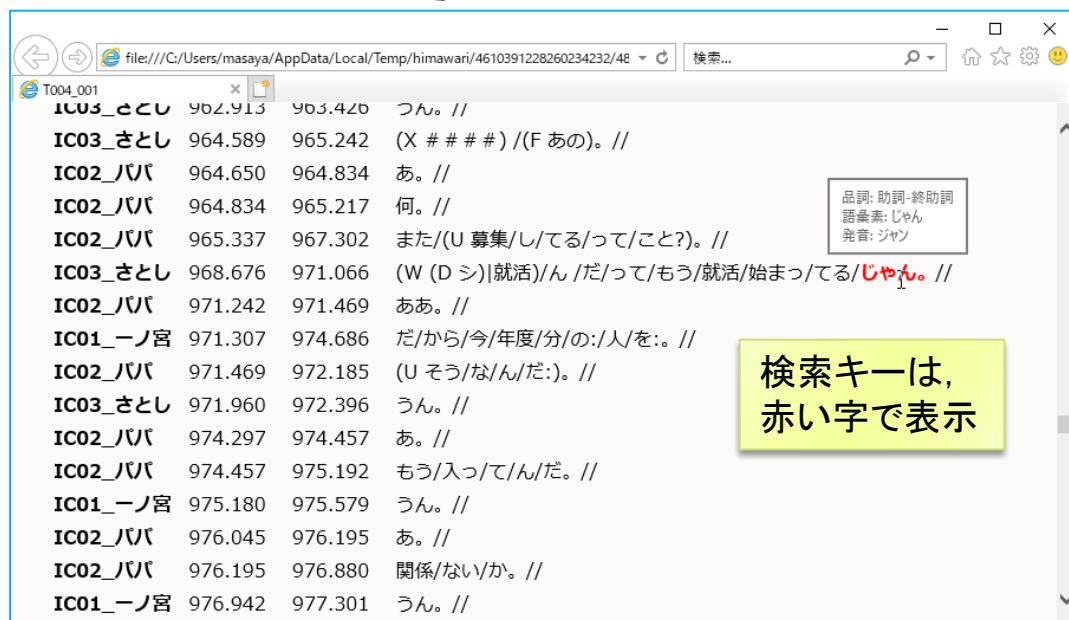
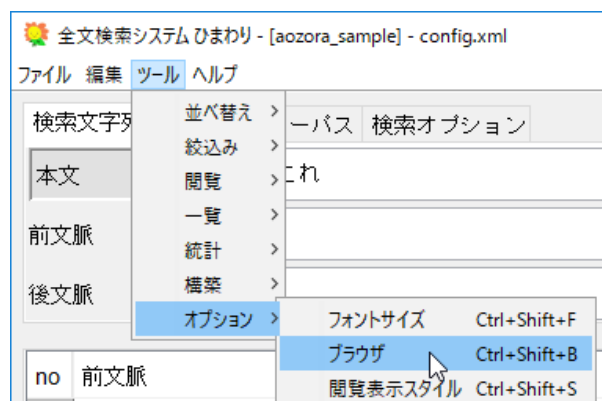
検索結果

転記テキストの閲覧

no	前文脈	キー	後文脈	会話ID	話者ID	話者ラベル	性別
1	ナはあの小ささがいい	じゃん	◇ あの細長さでさ	T010_004	T010	IC01_徹	男性
2	だよ キャッチする人	じゃん	◇ お前超怖えから	T010_004	T010_004	IC02_大場	男性
3	器吹い 腹式やってん	じゃん	◇ やってるにも関	T010_004	T		
4	てもう就活始まってる	じゃん	ああ だから今年度	T004_001	T		
5	ついてね あれもあん	じゃん	あのタッチするやつ	T010_004	T		
6	だからカットしに来る	じゃん	あー はいはいはい	T010_004	T010	IC01_徹	男性
7	ん うん ばちーなる	じゃん	あー 俺痛いじゃん	T010_004	T010	IC01_徹	男性

閲覧したい用例の「キー」列などをダブルクリック

■ 閲覧用のブラウザの変更



[ツール]⇒[オプション]⇒[ブラウザ]

話者，会話情報の閲覧

no	前文脈	キー	後文脈	会話ID	話者ID	話者ラベル	性別
1	ナはあの小ささがいい	じゃん	◇ あの細長さでさ	T010_004	T010	IC01_徹	男性
2	だよ キャッチする人	じゃん	◇ お前超怖えから	T010_004	T010_004	IC02_大場	男性
3	器吹い 腹式やってん	じゃん	◇ やってるにも関	T010_004	T010	IC01_徹	男性
4	てもう就活始まって	じゃん	ああ だから今年度	T004_001	T004_002	IC03_さと...	男性
5	ついてね あれもあん	じゃん	あのタッチするやつ	T010_004	T010	IC01_徹	男性
6	だからカットしに来る	じゃん	あー はいはいはい	T010_004	T010	IC01_徹	男性
7	ん うん ばちーなる	じゃん	あー 俺痛いじゃん	T010_004	T010	IC01_徹	男性

閲覧したい用例の「会話ID」
「話者ID」列をダブルクリック



話者ID

会話ID



会話DB

会話ID: T004_001

会話時間: 27

会話概要: 自宅で夫・息子と野球中継を見ながら夕食

話者数: 3

形式: 雑談

場所: 自宅

活動: 食事

話者間の関係性: 家族

備考: 夫・息子は巨人ファンで野球中継をよく見る。
時間帯が合えば家族揃って家や外で食事をする。
お酒を飲みながら食事することが多い。

OK

話者DB

話者ID: T004_002

年齢: 20-24歳

性別: 男性

職業: 会社員・役員・公務員・専門職

出身地: 東京都

居住地: 東京都

協力者からみた関係性: 家族親族_息子

備考: 就職1年目で一人暮らしを始めたところ。
姉と2人兄弟。
実家によく立ち寄る。

OK

会話一覧: [ツール] ⇒ [一覧] ⇒ [会話DB]
話者一覧: [ツール] ⇒ [一覧] ⇒ [話者DB]

検索結果のソート

列名を左クリック

no	前文脈	キー	後文脈	会話ID	話者ID	話者ラベル	性別
1	ナはあの小ささがいい	じゃん	◇ あの細長さでさ	T010_004	T010	IC01_徹	男性
2	だよ キャッチする人	じゃん	◇ お前超怖えから	T010_004	T010_004	IC02_大場	男性
3	器吹い 腹式やってん	じゃん	◇ やってるにも関	T010_004	T010	IC01_徹	男性
4	てもう就活始まってる	じゃん	ああ だから今年度	T004_001	T004_002	IC03_さと...	男性
5	ついてね あれもあん	じゃん	あのタッチするやつ	T010_004	T010	IC01_徹	男性
6	だからカットしに来る	じゃん	あー はいはいはい	T010_004	T010	IC01_徹	男性
7	ん うん ばちーなる	じゃん	あー 俺痛いじゃん	T010_004	T010	IC01_徹	男性
8	かみたいでさ全部やる	じゃん	うん うん あー	T010_004	T010_003	IC03_龍之...	男性
9	回ナセカンドに投げん	じゃん	うん うん うん	T010_004	T010	IC01_徹	男性
10	だからキャッチャー	じゃん	うん うん うん	T010_004	T010	IC01_徹	男性
11	たら絶対もう合わない	じゃん	うん うん だから	T010_004	T010	IC01_徹	男性
12	いや みんなねゆう	じゃん	うん うん んで俺	T010_004	T010	IC01_徹	男性

▶ 昇順・降順

- ▶ 列タイトルをクリックで、昇順・降順が切り替わる
- ▶ シフトを押しながらクリックすると、降順

▶ 複数列を考慮したい場合

- ▶ 優先順位の逆順でソートを実行

例:「性別」ごとに「後文脈」でソート
→ 「後文脈」「性別」の順

検索結果の絞り込み

▶ 検索時に指定

全文検索システム ひまわり - [日本語日常会話コーパス] - config.xml

ファイル 編集 ツール ヘルプ

検索文字列 フィルタ コーパス 検索オプション

性別	▼	男性	で始まる ▼
話者ID	▼		で始まる ▼
話者ラベル	▼		で始まる ▼

「性別」列が「男性」
で始まる結果のみに
絞り込まれる

▶ 検索後に絞り込み

no	前文脈	キー	後文脈	会話ID	話者ID	話者ラベル	性別	年齢
1	ナはあの小ささがいい	じゃん	◇ あの細長さでさ	T010_004	T010	IC01_徹	男性	
2	だよ キャッチする人	じゃん	◇ お前超怖えから	T010_004	T010_004	IC02_大場	男性	
3	開始し 照れか	じゃん	◇ やってるにも関	T010_004	T010	IC01_徹	男性	
4	ってるじゃん	じゃん	ああ だから今年度	T004_001	T004_002	IC03_さと...	男性	20-24歳
5	もあん	じゃん	あのタッチするやつ	T010_004	T010	IC01_徹	男性	20-24歳
6	に来る	じゃん	あー はいはいはい	T010_004	T010	IC01_徹	男性	20-24歳
7	ーなる	じゃん	あー 俺痛いじゃん	T010_004	T010	IC01_徹	男性	20-24歳

列名を右クリック

絞り込みたい値を選択
⇒右クリック⇒フィルタ
でもOK

検索結果の頻度集計

1. 集計したい列を選択

no	前文脈	キー	後文脈	会話ID	話者ID	話者ラベル	性別	年齢
1	ナはあの小ささがいい	じゃん	◇ あの細長さでさ	T010_004	T010	IC01_徹	男性	20-24歳
2	だよ キャッチする人	じゃん	◇ お前超怖えから	T010_004	T010_004	IC02_大場	男性	20-24歳
3	器吹い 腹式やってん	じゃん	◇ やってるにも関	T010_004	T010	IC01_徹	男性	20-24歳
4	てもう就活始まって	じゃん	ああ だから今年度	T004_001	T004_002	IC03_さと...	男性	20-24歳
5	ついてね あれもあん	じゃん	あのタッチするやつ	T010_004	T010	IC01_徹	男性	20-24歳
6	だからカットしに来る	じゃん	あー はいはいはい	T010_004	T010	IC01_徹	男性	20-24歳
7	ん うん ばちーなる	じゃん	あー 俺痛いじゃん	T010_004	T010	IC01_徹	男性	20-24歳
8	かみたいでさ全部やる	じゃん	うん うん あー	T010_004	T010_003	IC03_龍之...	男性	20-24歳
9	回ナセカンドに投げん	じゃん	うん うん うん	T010_004	T010	IC01_徹	男性	20-24歳
10	だからキャッチャー	じゃん	うん うん うん	T010_004	T010	IC01_徹	男性	20-24歳

複数の列を
選択することも可

離れた列の選択

- WindowsはCtrlキー
- macOSはcommandキー

2. 右クリック⇒「統計」

話者ID	話者ラベル	性別	年齢
T010	IC01_徹	男性	20-24歳
T010_004	IC02_大場	男性	
T010	IC01_徹	男性	
T004_002	IC03_さと...	男性	
T010	IC01_徹	男性	
T010	IC01_徹	男性	
T010	IC01_徹	男性	
T010_003	IC03_龍之...	男性	
T010	IC01_徹	男性	20-24歳
T010	IC01_徹	男性	20-24歳
T010	IC01_徹	男性	20-24歳
T010	IC01_徹	男性	20-24歳
T010_004	IC02_大場	男性	20-24歳



[5] 頻度：性別,年...		
ファイル 編集 ツール		
性別	年齢	頻度
男性	20-24歳	51
女性	35-39歳	9
女性	60-64歳	9
男性	5-9歳	1
女性	30-34歳	1
総数(延べ)：71, 異なり：5		

結果のエクスポート

▶ クリップボードを使用する方法

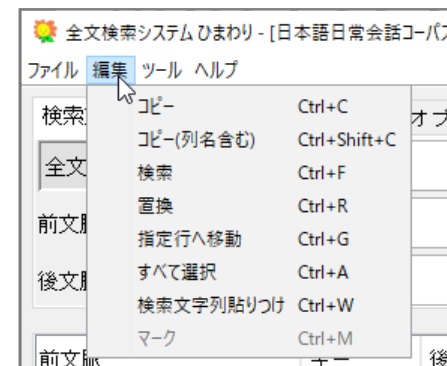
1. 結果を選択

- ▶ 全選択したい場合は, Ctrl キー + A

2. 選択範囲をコピー

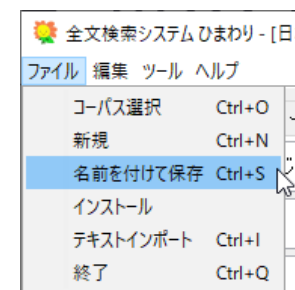
- ▶ 通常のコピー: Ctrl キー + C
- ▶ 列名を含めたコピー: Ctrl キー + Shift キー + C

3. Excel などにペースト



▶ [ファイル] ⇒ [名前を付けて保存]

- ▶ タブ区切りのテキストとして保存



動画の閲覧

講習会用パッケージには、会話ID「T001_009」の動画のみ収録

会話ID ^	話者ID	話者ラベル	性別	年齢
T001_009	T001_001	IC03_優香	女性	30-34歳 ^
T003_001	T003	IC01_由美	女性	35-39歳
T003_001	T003_002	IC03_大和	男性	5-9歳
T003_001	T003	IC01_由美	女性	35-39歳
T003_001	T003	IC01_由美	女性	35-39歳
T003_001	T003	IC01_由美	女性	35-39歳
T003_001	T003	IC01_由美	女性	35-39歳

閲覧したい用例の
「性別」か「年齢」列のセルを
ダブルクリック



観察支援システムFishWatchr

「注記連動」をクリックすると、
転記テキストが動画と連動してスクロール

注意

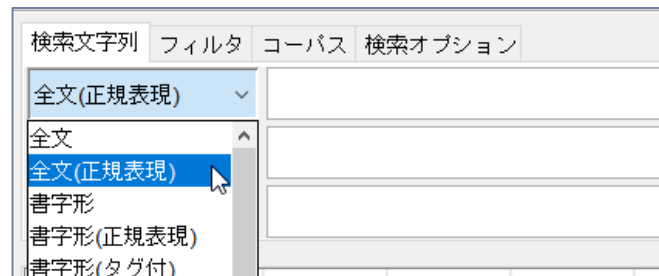
- この後の講習で使うので、再生を停止し、ウィンドウを「最小化」しておいてください
- 個別に起動するので、通常は、閲覧し終わったら終了したほうがよい

転記テキスト

検索機能の詳細

全文(正規表現)


- ▶ 本文検索に正規表現(Java)が利用可能
- ▶ 検索速度は「全文」検索より低速
- ▶ マッチングの範囲は、1発話単位(転記テキスト1行)



A) 「です。」

. (ピリオド)や
カッコは半角！

B) 「じゃ(ない|ねえ)」



C) 雑多な例

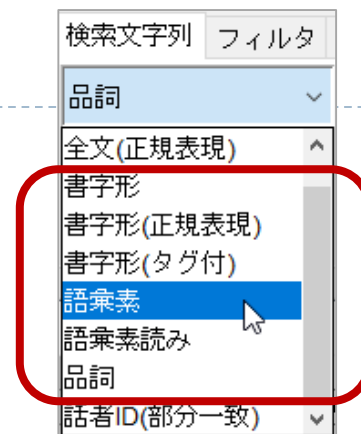
- ▶ 私[がは]
- ▶ です.*\$
- ▶ (..)¥1

macOSの場合、「¥」は逆スラッシュ (optionキー+「¥」) を使用

.	... 任意の1文字
(A B)	... AもしくはB
[がをにへ]	... 「が」「を」「に」「へ」のいずれか
^	... 行頭(この場合、発話単位頭)
\$... 行末(この場合、発話単位末)
*	... 直前要素の0個以上の繰り返し
+	... 直前要素の1個以上の繰り返し
()	... マッチした範囲を記録
¥1	... 1個目の記録した要素

単語(短単位)での検索

- ▶ マッチングの範囲は単語(短単位)
- ▶ 単位をまたいだ検索はできない
- ▶ 前後2単語の語彙素も表示(例:「語彙素1」「語彙素-1」)
- ▶ 「書字形(正規表現)」だけ、検索文字列の指定方法が異なる
- ▶ 詳細は、[ヘルプ]⇒[『ひまわり』マニュアル]参照



□ 「国」を含む単語

書字形
書字形(タグ付)
語彙素
語彙素読み
品詞

検索文字列	フィルタ	コーパス	検索
書字形	▼	国	
正規表現(前)			
正規表現(後)			

□ 「国」で始まる単語

検索文字列	フィルタ	コーパス	検索
書字形	▼	国	
正規表現(前)		^	
正規表現(後)			

□ 単語「国」のみ

検索文字列	フィルタ	コーパス	検索
書字形	▼	国	
正規表現(前)		^	
正規表現(後)		\$	

書字形(正規表現)

検索文字列	フィルタ	コーパス	検索
書字形(正規表現)	▼	国	
前文脈			
後文脈			

検索文字列	フィルタ	コーパス	検索
書字形(正規表現)	▼	^国	
前文脈			
後文脈			

検索文字列	フィルタ	コーパス	検索
書字形(正規表現)	▼	^国\$	
前文脈			
後文脈			

検索と転記テキストの関係

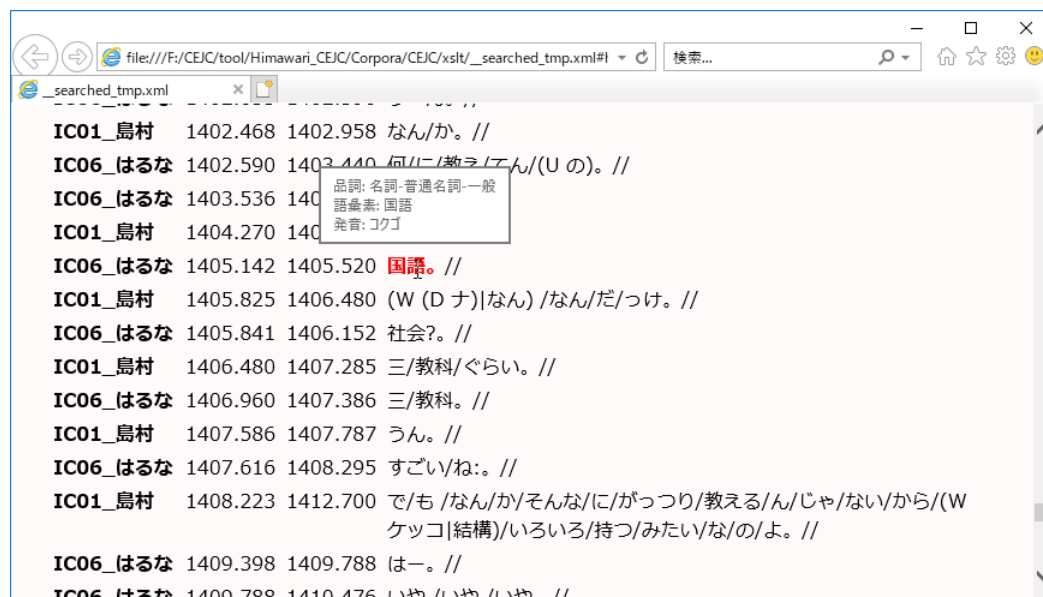
▶ 「全文」「書字形」などでの検索

- ▶ タグを除外した上で検索

▶ 「書字形(タグ付)」での検索

- ▶ タグを除外しないで検索

タグあり	タグなし
国語。	国語
社会?。	社会
(U の)。	の
(W ケッコ 結構)	結構
(W (D ナ) なん)	なん



ブラウザ表示されるのは、タグ付きの本文
(ただし、/は単語区切り。転記テキストのタグではなく、表示上の工夫)

「全文」検索では、タグや単語の区切りは無視して検索
(例: 「結構いろいろ」)

練習問題1

- ① 代名詞の「私」を検索
(「語彙素」で検索してみましょう)

- ② ①の検索結果の発音のバリエーションを集計
(検索結果の「発音」列や「キー」列で集計してみましょう)

コーパスの構造 と 基礎情報の集計

基礎情報の集計

▶ 基礎情報

- ▶ 「コーパス中の単語数」
- ▶ 「会話データ中の発話数」



量的な分析を行う際に必要

▶ CEJCの構造

- ▶ 会話データは発話列から構成
- ▶ 発話は単語列から構成

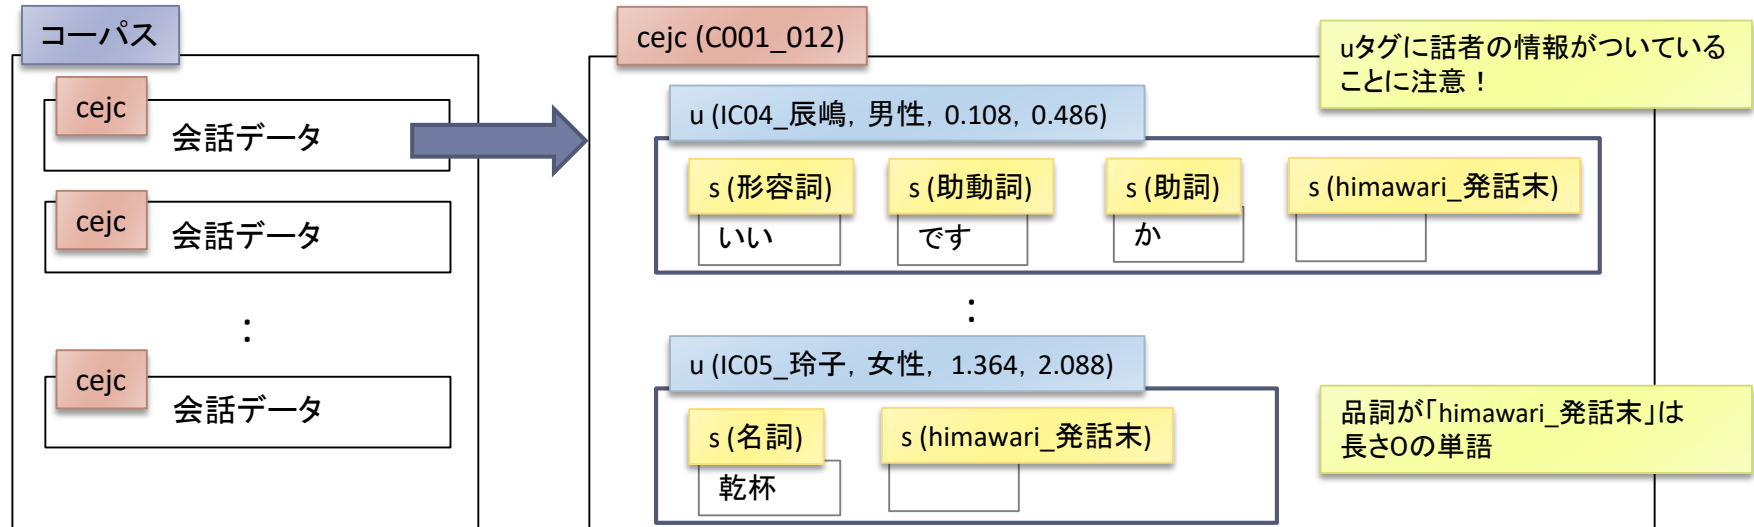
『ひまわり』は、構造を考慮した構成要素の集計が可能

話者ラベル	開始時刻	終了時刻	転記テキスト
IC04_辰嶋	0.108	0.486	いいですか?。//
IC05_玲子	0.519	0.715	うん。//
IC04_辰嶋	0.668	0.847	はい。//
IC04_辰嶋	0.956	1.364	じゃあ。//
IC05_玲子	0.956	1.221	はい。//
IC05_玲子	1.364	2.088	乾(Kバ:イ)杯。//
IC05_玲子	6.524	8.097	うはうは/みたい/な/感じ/だっ/た/よ。//
IC04_辰嶋	6.700	7.779	うーん。//

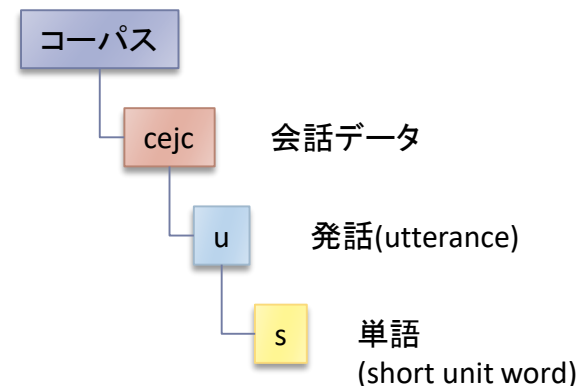
コーパス本体を見たい場合
Corpora/CEJC/corpus.xml

※「秀丸」などのテキストエディタを利用のこと

『ひまわり』用データの全体構造



タグの階層構造

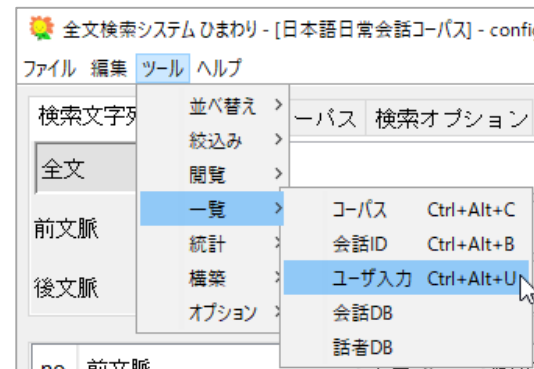


話者ラベル	開始時刻	終了時刻	転記テキスト
IC04_辰嶋	0.108	0.486	いい/です/か?。//
IC05_玲子	0.519	0.715	うん。//
IC04_辰嶋	0.668	0.847	はい。//
IC04_辰嶋	0.956	1.364	じゃあ。//
IC05_玲子	0.956	1.221	はい。//
IC05_玲子	1.364	2.088	乾(K パ:イ 杯)。//
IC05_玲子	6.524	8.097	うはうは/みたい/な/感じ/だった/よ。//
IC04_辰嶋	6.700	7.779	うーん。//

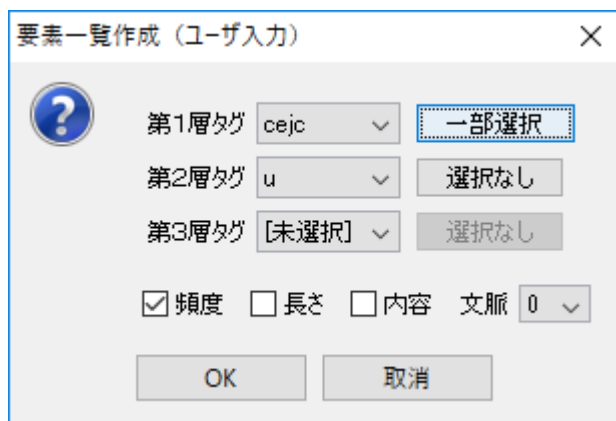
タグの集計

▶ [ツール]⇒[一覧]⇒ユーザ入力

- ▶ タグの階層構造を利用しつつ、タグの数や属性を集計する
- ▶ 例1： 発話数
- ▶ 例2： 語彙表



□ 各会話に含まれる発話数



- ▶ 頻度： 指定したタグの頻度
- ▶ 長さ： マークアップされている文字列の長さ（空白やXMLタグは除く）
- ▶ 内容： マークアップされている文字列
- ▶ 文脈： 後続する同種の要素の属性をn個表示（単語の場合n+1 gramになる）

タグの集計の例1

□ 会話一覧

要素一覧作成 (ユーザ入力)

第1層タグ cejc 一部選択

第2層タグ [未選択] 選択なし

第3層タグ [未選択] 選択なし

☒ 頻度 ☐ 長さ ☐ 内容 ☐ 文脈 0

OK 取消

要素一覧作成 (ユーザ入力)

☒ 会話ID
☐ {path}
☐ 話者間の関係性

☐ すべて選択

OK 取消

[1] ー... ー □ ×

ファイル 編集 ツール

cejc/@会話ID ^	頻度
T001_009	1
T003_001	1
T004_001	1
T004_013	1
T010_004	1

総数(延べ): 5, 異なり: 5

□ 発言者一覧

要素一覧作成 (ユーザ入力)

第1層タグ u 一部選択

第2層タグ [未選択] 選択なし

第3層タグ [未選択] 選択なし

☒ 頻度 ☐ 長さ ☐ 内容 ☐ 文脈 0

OK 取消

要素一覧作成 (ユーザ入力)

☐ 年齢
☐ 出身地
☐ コメント
☐ 終了時刻
☐ {n}
☐ 職業
☐ {residence}
☒ 性別
☐ 話者ラベル
☒ 話者ID
☐ 開始時刻

☐ すべて選択

OK 取消

[2] ー一覧: u ー □ ×

ファイル 編集 ツール

u/@性別 ^	u/@話者ID	頻度
女性	T003	147 ^
女性	T004_031	205
女性	T004	971
女性	T004_032	495
女性	T004_033	444
女性	T004_030	302
女性	T001_001	136
女性	T001_002	422
男性	T003_002	181
男性	T003_001	78 v

総数(延べ): 6027, 異なり: 16

タグの集計の例2

□ 語彙表

要素一覧作成 (ユーザ入力)

? 第1層タグ s 一部選択

第2層タグ [未選択] 選択なし

第3層タグ [未選択] 選択なし

☒ 頻度 ☐ 長さ ☐ 内容 文脈 0

OK 取消

要素一覧作成 (ユーザ入力)

? ☐ 仮名
☒ 活用型
☒ 語彙素読み
☐ 活用形
☐ 発音形出現形
☒ 語彙素
☐ {n}
☒ 品詞
☐ 発音
☐ タグ付き書字形
☐ 書字形

☐ すべて選択

OK 取消

□ 各会話に含まれる発話数

要素一覧作成 (ユーザ入力)

? 第1層タグ cejc 一部選択

第2層タグ u 選択なし

第3層タグ [未選択] 選択なし

☒ 頻度 ☐ 長さ ☐ 内容 文脈 0

OK 取消

要素一覧作成 (ユーザ入力)

? ☒ 発話ID
☐ {path}
☐ 話者間の関係性

☐ すべて選択

OK 取消

タグの集計時のフィルタ

- ▶ タグ集計時にもフィルタをかけることが可能
 - ▶ 例：品詞名に「himawari」を含む単語は集計から除外

検索文字列	フィルタ	コーパス	検索オプション
品詞	himawari	を含まない	
話者ID		で始まる	
話者ラベル		で始まる	

- ・ フィルタの対象は、集計する項目に必ず含めること
- ・ 左例の場合、「要素一覧作成」ダイアログで、sの「品詞」属性を含める

[27] 一覧: s

ファイル 編集 ツール

s/@品詞	頻度
himawari 発話末	147867
助動詞	76091
感動詞-一般	57729
名詞-普通名詞-...	53020
助詞-格助詞	51714
助詞-終助詞	46466
副詞	37297
動詞-一般	34715
動詞-非自立可能	29510
助詞-接続助詞	27311

総数(延べ): 770169, 異なり: 49

フィルタをかけると...



[5] 一覧: s

ファイル 編集 ツール

s/@品詞	頻度
助動詞	76091
感動詞-一般	57729
名詞-普通名詞-...	53020
助詞-格助詞	51714
助詞-終助詞	46466
副詞	37297
動詞-一般	34715
動詞-非自立可能	29510
助詞-接続助詞	27311
代名詞	23579

総数(延べ): 622302, 異なり: 48

練習問題2

- ① 会話データごとの単語数を求める
(cejcとsタグを使いましょう)

- ② 会話データごとに、品詞が「himawari_発話末」の語数を求める
(フィルタで「品詞」が「himawari」で始まるものに限定しましょう)

動画の閲覧・アノテーション

FishWatchr の紹介

▶ 特徴

- ▶ 『ひまわり』で検索した場所の映像を見るのに便利
- ▶ 転記テキストと映像を同期させて見ることができる
- ▶ 簡単に注釈付け(アノテーション)できる

▶ 簡易的な利用を想定

⇒ 専門的なアノテーションや分析を行う場合は, ELAN, Praatを利用のこと

- ▶ 元々, 大学におけるディスカッション練習を, 学生がリアルタイムに観察するためのシステムとして開発しました

動画の再生位置の指定

▶ 三つの方法で指定可能

プロット画面に何も表示されない場合、「リセット」してください

②ダブルクリック
(横軸は時間)

③クリック

①「番号」列をダブルクリック

現在の再生位置

この色の範囲は、
現在位置の前後
10秒

番号	時間	注釈者	話者	ラベル	セット	転記テキスト	補助情報
72	00:01:43	system	IC04_広瀬		T001_009_...	そうなんすか。	
73	00:01:43	system	IC02_義母		T001_009_...	うん。	
74	00:01:43	system	IC02_義母		T001_009_...	なんか肺ガンとかって出た。	
75	00:01:45	system	IC02_義母		T001_009_...	うん。	
76	00:01:46	system	IC02_義母		T001_009_...	で どうもおかしいなみたいな感じだったんだけど。	
77	00:01:48	system	IC03_優香		T001_009_...	でもこの間の温泉のやつお治ってたじゃん。	
78	00:01:48	system	IC02_義母		T001_009_...	うん。	
79	00:01:50	system	IC02_義母		T001_009_...	出たたね。	
80	00:01:51	system	IC03_優香		T001_009_...	ちょっと。	
81	00:01:51	system	IC02_義母		T001_009_...	そう そう。	

動画の再生(微調整)

- 再生速度の変更
- 前後のコメント(発話)へのジャンプ

The screenshot shows the FishWatchr application window. The 'コントロール' (Control) menu is open, highlighting '再生速度+' (Increase playback speed) with the keyboard shortcut 'Ctrl-ピリオド' (Ctrl-Period). The playback controls at the bottom are also highlighted with a red box, showing buttons for previous, play/pause, next, and stop. The video player shows a scene with people in a room. The transcript at the bottom lists dialogue with timestamps and speaker labels.

再生開始時の時間補正
2秒前から再生 (デフォルト)
[オプション]⇒[再生位置の補正]

再生のコントロールは
すべてキーボードからも可能

番号	時刻	話者	ラベル	セット	転記テキスト	補助情報
		IC04_広瀬		T001_009_...	でもなん(W(Dブ)分類)分類でゆうと一緒です。	
		IC02_義母		T001_009_...	(Wモ)もうとにかく。	
		IC02_義母		T001_009_...	分類?。	
		IC02_義母		T001_009_...	(Fあの)ねなんだっけーチャンのアナウンサーなんだっけ。	
132	00:02:39	system	IC03_優香	T001_009_...	有働さん。	
133	00:02:40	system	IC02_義母	T001_009_...	有働さん 年がら年中ゆわれる。	
134	00:02:42	system	IC04_広瀬	T001_009_...	(T有働さんて誰だっけ)。	
135	00:02:43	system	IC03_優香	T001_009_...	いのっちと出てる人。@いのっち=ジャニーズグループV6メンバー・井ノ原快彦のこと	
136	00:02:45	system	IC04_広瀬	T001_009_...	あー。	
137	00:02:45	system	IC02_義母	T001_009_...	うーん。	

発話のプロット画面

『日本語日常会話コーパス』の場合は、
「表示」を「話者」に変更するのが便利

ドラッグすると
拡大表示
(戻すときは「リセット」)

発話の
ヒストグラム

番号	時間	注釈者	話者	ラベル	セット	転記テキスト	補助情報
542	00:13:13	system	IC02_義母		T001_009_...	(Dイ) なかなか行かないよね。	
543	00:13:15	system	IC04_広瀬		T001_009_...	(T(Uそう)すね)。	
544	00:13:15	system	IC02_義母		T001_009_...	うん。	
545	00:13:16	system	IC04_広瀬		T001_009_...	東京東京の地震発生率ってなん ここ何年で 何年かで七十パーセントでしたっけ。	
546	00:13:23	system	IC02_義母		T001_009_...	知らないけど。	
547	00:13:24	system	IC02_義母		T001_009_...	とにかくわたし(私たち)小さいころから もう地震は来るってゆうので(Fあの:)小(W...	
548	00:13:35	system	IC02_義母		T001_009_...	でうん 年に二三回? ちゃんと防災訓練があった。	
549	00:13:40	system	IC02_義母		T001_009_...	うん。	
550	00:13:40	system	IC02_義母		T001_009_...	もうほんとにだから 五十(T五年ぐらい前)四五年前からあったから。	
551	00:13:45	system	IC04_広瀬		T001_009_...	(Tほー)。	

発話の絞り込み(1)

▶ 列名の部分を右クリックすると絞り込み

[resources/FishWatchr/xml/T001_009.fw.xml] - FishWatchr

ファイル コントロール 注釈 分析 オプション ヘルプ

全体 詳細

表示 ラベル ▼ ☒ フィルタ連動 リセット < >

ラベル1
ラベル2

00:10:00 00:19:19

番号	時間	注釈者	話者	ラベル	セット	転記テキスト	補助情報
72	00:01:43	system	IC04_広瀬	[検索文字列の指定]	01_009...	そうなんすか。	
73	00:01:43	system	IC02_義母	IC02_義母	01_009...	うん。	
74	00:01:43	system	IC02_義母	IC02_義母	01_009...	なんか肺ガンとかって出た。	
75	00:01:45	system	IC02_義母	IC03_優香	01_009...	うん。	
76	00:01:46	system	IC02_義母	IC04_広瀬	01_009...	でもまあおかしいなみたいな感じだったんだけど。	
77	00:01:48	system	IC03_優香		T001_009...	でもこの間の温泉のやつは治ってたじゃん。	
78	00:01:48	system	IC02_義母				
79	00:01:50	system	IC02_義母				
80	00:01:51	system	IC03_優香				
81	00:01:51	system	IC02_義母		T001_009...	そうそう。	

ラベル 1 [1]
ラベル 2 [2]

列名の部分を
クリック

選択メニュー

絞り込みを解除するには、選択メニューから「全フィルタ解除」を実行

発話の絞り込み(2)

▶ 文字列を指定しての絞り込み

[resources/FishWatchr/xml/T001_009.fw.xml] - FishWatchr
ファイル コントロール 注釈 分析 オプション ヘルプ

全体 詳細
表示 話者 ☒ フィルタ連動 リセット < >

IC02_義
IC03_優
IC04_広

00:13:27 00:19:19

番号	時間	注釈者	話者	ラベル	セット	転記テキスト	補助情報
542	00:13:13	system	IC02_義母		T001_009...	(Dイ) なかなか行かないよね。	
543	00:13:15	system	IC04_広瀬				
544	00:13:15	system	IC02_義母				
545	00:13:16	system	IC04_広瀬				
546	00:13:23	system	IC02_義母				
547	00:13:24	system	IC02_義母				
548	00:13:35	system	IC02_義母				
549	00:13:40	system	IC02_義母				
550	00:13:40	system	IC02_義母				
551	00:13:45	system	IC04_広瀬				

絞り込み条件の指定

検索文字列の指定


(D ア) スミのパンのね なんだろう (D ア) # # # # #
(D イ) なかなか行かないよね。
(D イ) 効く人で効くタイミングの時もあれば 効かないタイミングの時もあるし。
(D オ) え。
(D オー) お手伝いもね: うん わたしはい。
(D ハ) (M ハ) リカとか (M ハ) ルタとか なんとかって ゆう そう ゆう あれの (U こと)。
(D ハ)。

OK 取消

検索文字列の例

- 例1: 「うん」
- 例2: 「L」 ... 笑いを含む発話
- 例3: 「¥?」 ... 疑問上昇調の発話

※macの場合¥を半角の＼に
※¥を入れるのは、?が正規表現のメタ文字のため



アノテーション(追加と削除)

データの保存

- 変更すると、終了時に自動保存
- ただし、『ひまわり』やdataフォルダのデータには影響なし

The screenshot shows the FishWatchr software interface. At the top, there's a menu bar with 'ファイル', 'コントロール', '注釈', '分析', 'オプション', and 'ヘルプ'. Below the menu, there's a '全体' (Overall) tab and a '詳細' (Details) tab. The '全体' tab is active, showing a video feed of a person in a kitchen. Below the video, there's a list of annotations with columns for '番号' (Number), '時間' (Time), '注釈者' (Annotator), '話者' (Speaker), 'ラベル' (Label), 'セット' (Set), '転記テキスト' (Transcription Text), and '補助情報' (Auxiliary Information). The '補助情報' column is highlighted with a red box. Below the table, there are two buttons labeled 'ラベル 1' and 'ラベル 2', which are also highlighted with a red box. A red arrow points to the '補助情報' column header.

番号	時間	注釈者	話者	ラベル	セット	転記テキスト	補助情報
543	00:13:15	system	IC04_広瀬		T001_009...	(T(うそう)すね。)	
544	00:13:15	system	IC02_義母		T001_009...	うん。	
545	00:13:16	system	IC04_広瀬		T001_009...	東京東京の地震発生率って:なんここ何年で何年かで七十パーセントでしたっけ。	
546	00:13:23	system	IC02_義母		T001_009...	知らないけど。	
547	00:13:24	system	IC02_義母		T001_009...	とにかくわたし(私たち)小さいころからもう地震は来るってゆうので(Fあの:)小(W...	
800	00:13:27	masaya_in...	不特定	ラベル1	T001_009.f...		
548	00:13:35	system	IC02_義母		T001_009...	でうん年に二三回?ちゃんと防災訓練があった。	
549	00:13:40	system	IC02_義母		T001_009...	うん。	
550	00:13:40	system	IC02_義母		T001_009...	もうほんとにだから五十(T五年ぐらい前)四五年前からあったから。	
551	00:13:45	system	IC04_広瀬		T001_009...	(Tほー。	

「注釈者」「話者」「ラベル」「セット」
「補助情報」列は変更可

- コメントは「補助情報」列に記入
- 直接入力できるが、タブをクリックすると、入力用のフォームから入力可

アノテーションボタン

- 再生位置に1行追加
(一つのアノテーション)
- 削除は、削除したい行で、
右クリック⇒[行の削除]

アノテーション(ラベルの変更)

▶ ラベルは自由に定義可

「マーク色」はアノテーション・プロット時の色

ラベルの設定

ラベル	マーク色
うなずき	赤
疑問	黄
躊躇	緑
ジェスチャー	青

OK 取消

番号	時間	注釈者	話者	ラベル	セット
543	00:13:15	system	IC04_広瀬		T001_009_...
544	00:13:15	system	IC02_義母		T001_009_...
545	00:13:16	system	IC04_広瀬		T001_009_...
546	00:13:23	system	IC02_義母		T001_009_...
547	00:13:24	system	IC02_義母		T001_009_...
800	00:13:27	masaya_in...	不特定	うなずき	T001_009.f...
548	00:13:35	system	IC02_義母		T001_009_...
549	00:13:40	system	IC02_義母		T001_009_...
550	00:13:40	system	IC02_義母		T001_009_...
551	00:13:45	system	IC04_広瀬		T001_009_...

うなずき [1] 疑問 [2] 躊躇 [3] ジェスチャー [4]

ただし、ラベルの設定は個々のファイルごと

アノテーション結果の利用

- ▶ 講習会用のパッケージからFishWatchrを単独で起動するのは難しいので、独立してインストールして、利用するのがお薦め
 - ▶ [ヘルプ] ⇒ [マニュアル]
- ▶ アノテーション結果ファイルの所在(※移動しないこと)
 - ▶ tool/Himawari_CEJC/resources/FishWatchr/xml
 - ▶ FishWatchrにドラッグ & ドロップすると、直接閲覧できる
- ▶ バックアップファイル
 - ▶ tool/Himawari_CEJC/resources/FishWatchr/xml/BAK
 - ▶ 保存前のファイルはすべてバックアップされる
 - ▶ 元に戻したい場合は、一番古いファイルを使えばよい

おわりに

- ▶ 全文検索システム『ひまわり』を使った『日本語日常会話コーパス』の利用方法を紹介
 - ▶ 検索機能(全文検索・単語検索)
 - ▶ コーパスの構造を利用した基礎データの集計方法
 - ▶ FishWatchrによる動画の再生・簡単なアノテーション
- ▶ さらに詳しく知るには
 - ▶ [ヘルプ]⇒[マニュアル]
 - ▶ 資料末の参考資料を参照

参考資料

- ▶ 全文検索システム『ひまわり』
(<http://www2.ninjal.ac.jp/lrc/index.php?himawari>)
- ▶ [ヘルプ]⇒[『ひまわり』マニュアル]
- ▶ 観察支援システムFishWatchr
(<http://www2.ninjal.ac.jp/lrc/index.php?fw>)

- ▶ 正規表現
 - ▶ Java Pattern クラス (『ひまわり』で利用できる正規表現の仕様)
(<https://docs.oracle.com/javase/jp/8/docs/api/java/util/regex/Pattern.html>)
 - ▶ 「Java正規表現の使い方」
(<http://www.javadrive.jp/regex/>)

練習問題1の解答例

- ① 代名詞の「私」を検索
(「語彙素」で検索してみましょう)

検索文字列	フィルタ	コーパス	検索オプション
語彙素	私		
正規表現(前)	^		正規表現
正規表現(後)	\$		正規表現

- ② 発音のバリエーションを集計
(検索結果の「発音」列や「キー」列で集計してみましょう)

素読み	発音形出...	発音	書字形	タグ付き...	語彙素-2	語
クシ	アタクシ	アタクシ	あたし	あたし	から	
クシ	アタクシ	アタ	コピー	あたし		も
シ	アタシ	アタ	コピー(列名含む)	あたし。		
シ	アタシ	アタ	全選択	あたし。	の	
シ	アタシ	アタ	置換	あたし。	うん	
シ	アタシ	アタ	フィルタ	あたし。	よ	
シ	アタシ	アタ	統計	あたし。	もの	
シ	アタシ	アタシ	あたし	あたし。	よ	
シ	アタシ	アタシ	あたし	あたし？		此

練習問題2の解答例

① 会話データごとの単語数を求める

要素一覧作成 (ユーザ入力)

第1層タグ: cejc 一部選択

第2層タグ: s 選択なし

第3層タグ: [未選択] 選択なし

☒ 頻度 ☐ 長さ ☐ 内容 文脈 0

OK 取消

cejcの属性「会話ID」チェック

cejc/@会...	頻度
C001_001	11929
C001_002	4659
C001_005	2513
C001_007	6873
C001_012	8430
C002_003	925
C002_004	3396
C002_006a	3669

総数(延べ): 770169, 異なり: 1...

② 会話データごとに、品詞が「himawari_発話末」の語数を求める

検索文字列 フィルタ コーパス 検索オプション

品詞 himawari で始まる

話者ID で始まる

話者ラベル で始まる

要素一覧作成 (ユーザ入力)

第1層タグ: cejc 一部選択

第2層タグ: s 一部選択

第3層タグ: [未選択] 選択なし

☒ 頻度 ☐ 長さ ☐ 内容 文脈 0

OK 取消

- cejcの「会話ID」属性チェック
- sの「品詞」属性チェック